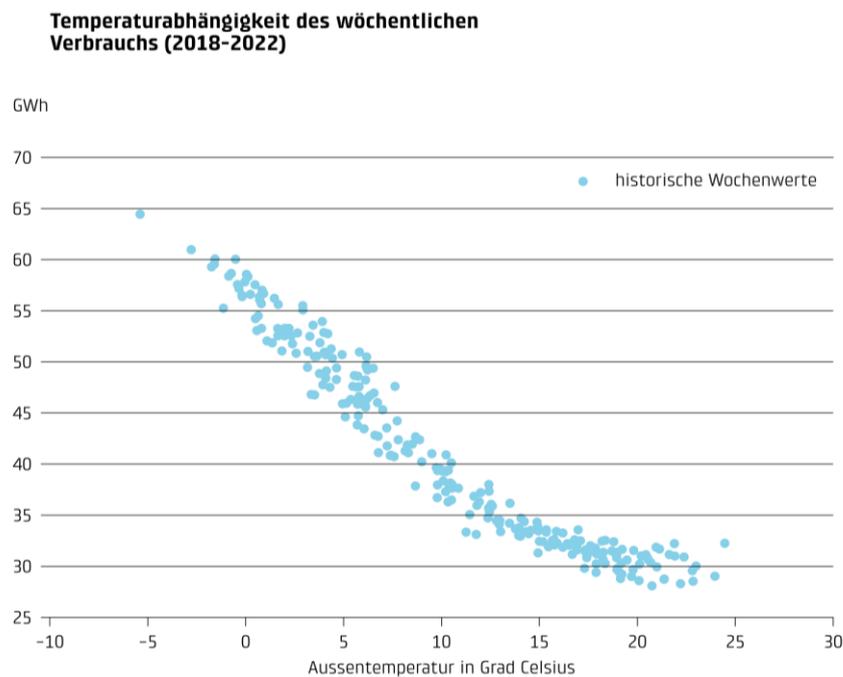


## Hintergrundinformationen zur Modellierung und der statistischen Analyse

Im Folgenden finden Interessierte tiefergehende technische Informationen.

### Berücksichtigung der Temperatur

Der Stromverbrauch der Grundversorgung zeigt eine starke Abhängigkeit von der Aussen-temperatur, unter anderem auf Grund von Wärmepumpen und Elektroheizungen. Der Zusammenhang ist in der Grafik 1 anhand historischer Wochenwerte für Verbrauch und Temperatur dargestellt.



Grafik 1: Temperaturabhängigkeit des wöchentlichen Verbrauchs (2018-2022)

Um mögliche Einspareffekte durch die Stromsparbemühungen zu analysieren, muss dieser Zusammenhang berücksichtigt werden. Eine milde Witterung verringert den Heizbedarf und kann so ebenfalls zu einem geringeren Stromverbrauch führen ohne eine Verhaltensänderung der Verbraucherinnen und Verbraucher. Das im folgenden Abschnitt beschriebene Modell berechnet daher die erwartete Verbrauchsmenge basierend auf den Temperaturen der Woche und der gezeigten Temperaturabhängigkeit des Verbrauchs.

### Schätzung des Photovoltaik-Eigenverbrauchs

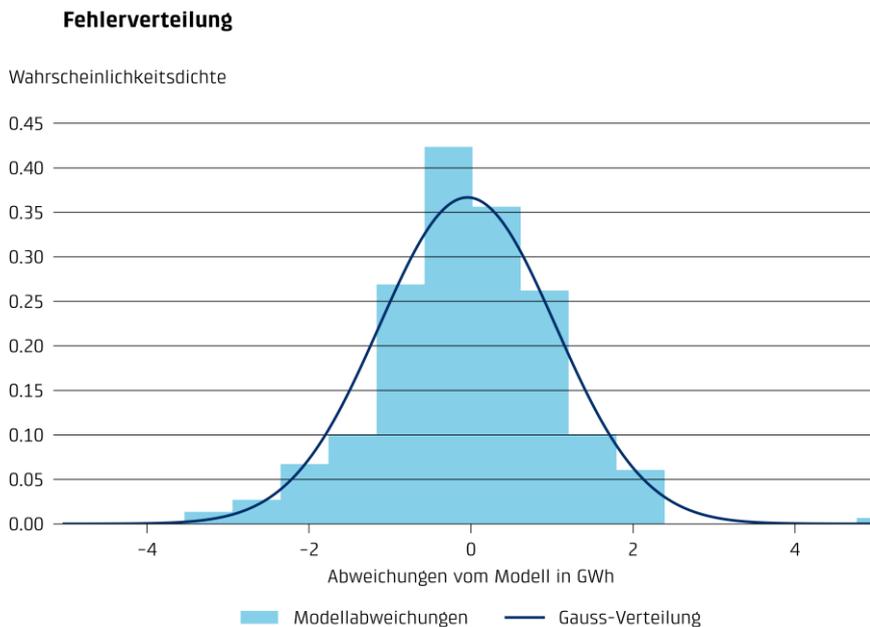
Im BKW-Gebiet gibt es viele Photovoltaik (PV)-Anlagen, die Strom produzieren, welcher teilweise direkt vor Ort verbraucht wird (Eigenverbrauch). Diese Mengen können jedoch nicht direkt und zeitnah gemessen werden. Dies betrifft alle kleinen Anlagen ohne Lastgangmessung. Die BKW ist primär in der Lage die Entnahme aus dem Stromnetz zu messen. Um den kompletten Verbrauch abzuschätzen, muss deshalb die Produktion dieser PV-Anlagen mit einem Modell simuliert und zur Stromentnahme aus dem Netz addiert werden. Die gezeigten Verbrauchswerte entsprechen somit dem kompletten Verbrauch der Kundinnen und Kunden in der Grundversorgung inkl. Eigenverbrauch.

## Statistische Analyse

Das statistische Modell basiert auf einer multiplen linearen Regression. Das heisst, der wöchentliche Stromverbrauch wird als Summe mehrerer gewichteter Einflussvariablen (sog. Regressoren) modelliert. Die optimale Gewichtung ist zentral für die Qualität des Modells und kann mittels historischer Daten und unterschiedlicher Algorithmen berechnet werden (am beliebtesten ist dabei die "Methode der kleinsten Quadrate").

Die Wahl der Regressoren ist ebenso wichtig für die Aussagekraft des Modells: Ein Einflussfaktor wie die Aussentemperatur kann in unterschiedliche Regressoren übersetzt werden. Beispielsweise können die wöchentliche Durchschnittstemperatur, die Maximal- und Minimaltemperatur oder auch Temperaturveränderungen im Modell als Regressoren verwendet werden. Die Konstruktion und Auswahl von Regressoren wird auch als "feature engineering" bezeichnet.

Die Qualität eines linearen Regressionsmodells muss zwingend anhand mehrerer Faktoren überprüft werden. Ein wichtiger Anhaltspunkt liefert dabei die statistische Verteilung des Modellfehlers, wenn das Modell auf historische Daten angewandt wird. Eine korrekte Auswahl der Regressoren und deren optimale Gewichtung zeigt sich darin, dass dieser Fehler grob einer Gauss-Verteilung (Glockenform) folgt.



Grafik 2: Fehlverteilung

Ein weiteres Qualitätsmerkmal liegt in der statistischen Unabhängigkeit des Modellfehlers. Allerdings ist dieses beim vorliegendem Verbrauchsmodell nicht automatisch erfüllt. Ein Verbrauch über der Modellerwartung in einer Woche erhöht die Wahrscheinlichkeit, dass auch in der Folgewoche der Verbrauch oberhalb des Modells liegt. (Die Ursachen könnten zum Beispiel weitere Wettereffekte sein oder nicht modellierte Einflussfaktoren, welche sich über mehrere Wochen hinweg erstrecken.) Der Effekt wurde für den Zeitraum 2018–2022 quantifiziert und durch eine sog. Cochrane-Orcutt-Schätzung korrigiert.

Ein grosser Vorteil von linearen Regressionsmodellen im Vergleich zu moderneren Methoden des maschinellen Lernens ist die einfache Berechenbarkeit von Unsicherheiten in Form von Konfidenzintervallen (im Text bisher Spannweite Verbrauchserwartung genannt). Die Konfidenzintervalle widerspiegeln dabei nicht nur die natürlichen Fluktuationen, welche

nicht durch die modellierten Regressoren erklärt werden, sondern auch die Unsicherheit im Modell. Das heisst, die optimale Gewichtung der Einflussfaktoren anhand von historischen Daten ist selbst mit einer Unsicherheit behaftet. Das Ergebnis der vorliegenden Modellierung ist folglich eine Spannweite der wöchentlichen Verbrauchsmenge, in der man einzelne Wochenwerte in 95% aller Fälle erwartet, falls keine Einsparbemühungen stattgefunden haben.

Ausserdem ermöglichen lineare Regressionsmodelle vielfältige Analysen. Zum Beispiel können im vorliegenden Verbrauchsmodell die Wochenwerte und ihre Unsicherheiten in Monats- oder Quartalswerte aggregiert werden. Durch Betrachtung längerer Zeiträume reduzieren sich die Unsicherheiten, da sich statistische Schwankungen über die Zeit mitteln. (Dies gilt aber wiederum nur unter gewissen Bedingungen statistischer Unabhängigkeit.) Das heisst, selbst wenn einzelne Wochenwerte nur insignifikant von der Modellerwartung abweichen, kann eine Aggregation eine signifikante Abweichung über einen längeren Zeitraum zu Tage fördern. Dies ist in den summierten Daten seit September der Fall. Die dabei angegebenen Unsicherheiten beziehen sich auf eine Wahrscheinlichkeit von 68%, dass der tatsächliche Minderverbrauch in diesem Zeitraum innerhalb des Unsicherheitsbereichs liegt.

Warum hilft ein Regressionsmodell eine Reduktion im Stromverbrauch zu identifizieren? Neu beobachtete wöchentliche Verbrauchswerte, welche über längere Zeit signifikant von der Modellerwartung abweichen sind ein Indiz dafür, dass das Regressionsmodell nicht mehr aussagekräftig ist. Da das Modell ausschliesslich auf historischen Daten von 2018 bis August 2022 beruht, folgt daraus, dass seit September 2022 ein neuer Faktor den wöchentlichen Stromverbrauch massgeblich beeinflusst. Es ist naheliegend, dass dahinter die Aufrufe zum Stromsparen stehen, aber ein kausaler Zusammenhang kann mit dieser Art von Analyse nicht bewiesen werden.